

SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

ZAVRŠNI RAD

Igor Kuš

Zagreb, 2014.

SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

ZAVRŠNI RAD

Mentori:

prof. dr. sc. Mario Štorga

Student:

Igor Kuš

Zagreb, 2014.



SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE



Središnje povjerenstvo za završne i diplomske ispite
Povjerenstvo za završne ispite studija strojarstva za smjerove:
proizvodno inženjerstvo, računalno inženjerstvo, industrijsko inženjerstvo i menadžment, inženjerstvo
materijala i mehatronika i robotika

Sveučilište u Zagrebu Fakultet strojarstva i brodogradnje	
Datum	Prilog
Klasa:	
Ur.broj:	

ZAVRŠNI ZADATAK

Student: **Igor Kuš**

Mat. br.: **0035176220**

Naslov rada na hrvatskom jeziku: **SMARTCITY SUSTAV ZA PRAĆENJE UDOBNOSTI VOŽNJE**

Naslov rada na engleskom jeziku: **SMARTCITY SYSTEM FOR DRIVE COMFORT TRACKING**

Opis zadatka:

SmartCity inicijativa naglašava važnost informacijske i komunikacijske tehnologije za razvoj gradova s posebnim fokusom na unapređenje dvaju aspekata – poboljšanje kvalitete života i očuvanje okoliša. Mnogobrojna rješenja koja se danas razvijaju u ovom području koriste mogućnosti suvremenih pametnih telefona za prikupljanje podataka te interakciju korisnika i javnih/privatnih službi s tim ciljem. Jedan od segementa koji je specifičan za naše područje je loša cestovna infrastruktura, pri čemu su pojedine prometnice zbog dugogodišnjeg lošeg održavanja u stanju koje nije primjereno suvremenim standardima kvalitete vožnje. To s jedne strane ima loš utjecaj na mehaniku vozila, ali i na kvalitetu vožnje putnika u tim vozilima.

Stoga je u okviru ovog rada potrebno uz korištenje GPS prijemnika i senzora pokreta koji postoje u suvremenim pametnim telefonima osmisliti i realizirati programsku aplikaciju koja će biježiti udare i vibracije uzrokovane oštećenjima na cestama za specifičnu brzinu vožnje, te na taj način vlasnicima automobila i ovlaštenim servisima omogućiti procjenu stanja sustava ovjesa i istrošenosti dijelova te planiranje servisnih intervala sukladno tome.

U radu je potrebno:

- definirati listu zahtjeva za razvoj aplikacije,
- kreirati dijagrame korištenja i funkcijski model aplikacije,
- kreirati model podataka i dijagram aktivnosti,
- realizirati aplikaciju prema navedenim modelima u razvojnom okruženju za mobilnih aplikacija,
- testirati i vrednovati uspješnost realizacije.

Opseg funkcionalnosti i realizacije dogovoriti tijekom izrade rada.

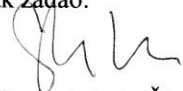
U radu navesti korištenu literaturu i eventualno dobivenu pomoć.

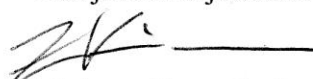
Zadatak zadan:
11. studenog 2013.

Rok predaje rada:
1. rok: 21. veljače 2014.
2. rok: 12. rujna 2014.

Predviđeni datumi obrane:
1. rok: 3., 4. i 5. ožujka 2014.
2. rok: 22., 23. i 24. rujna 2014.

Zadatak zadao:


Prof. dr. sc. Mario Štorga

Predsjednik Povjerenstva:

Prof. dr. sc. Zoran Kunica

Izjavljujem da sam ovaj rad izradio samostalno koristeći stečena znanja tijekom studija i navedenu literaturu.

Zahvale:

Zahvaljujem se svom mentoru prof.dr.sc. Mariu Štorgi koji je svojim stručnim i znanstvenim savjetima vodio i usmjeravao kroz temu rada, na strpljenju i savjetima tijekom izrade i pisanja rada te ugodnoj suradnji. Srdačno zahvaljujem dipl.ing Lucijanu Stamaću na stručnoj podršci te kolegi Mirku Rastoviću na suradnji kroz rad.

Hvala svim profesorima, kolegama i prijateljima.

Posebno hvala mojim roditeljima koji su mi omogućili studiranje te zajedno sa sestrom pružili podršku tokom studiranja.

Igor Kuš

SADRŽAJ

1. UVOD.....	1
1.1. Smart City	1
1.2. Smart City danas	1
1.3. Mobilna tehnologija i Smart City.....	2
1.4. Stanje prometnica u Republici Hrvatskoj	3
2. ROAD QUALITY SUSTAV.....	4
2.1. Oštećenja na ovjesu automobila.....	4
2.2. Utjecaj oštećenih prometnica na udobnost vožnje	4
2.3. Road Quality rješenja.....	4
3. DINAMIKA VOZILA.....	7
3.1. Ovjes automobila	9
4. UTVRĐIVANJE MOGUĆNOSTI RAZVOJA ROAD QUALITY SUSTAVA	12
5. MODEL PODATAKA I DIJAGRAM FUNKCIJA ZA SUSTAV ZA PRAĆENJE UDOBNOSTI VOŽNJE	15
5.1. Modeliranje funkcija pomoću toka za Road Quality sustav	17
5.2. Model podataka.....	17
6. RAZVOJ ROAD QUALITY APLIKACIJE	19
6.1. Operativni sustav i razvojno okruženje.....	19
6.2. Road Quality aktivnosti	20
7. REZULTATI TESTIRANJA ROAD QUALITY SUSTAVA	26
7.1. Testiranje Toyota Yaris.....	26
7.2. Testiranje Citroen C5	30
8. ZAKLJUČAK.....	33
9. LITERATURA	35
10. PRILOZI.....	37
10.1. Model funkcija sustava pomoću toka.....	37
10.2. EXPRESS-G dijagram podataka.....	38
10.3. UML dijagram aktivnosti.....	39

POPIS SLIKA

Slika 1.	Uređaj za ispitivanje podvozja [6].....	6
Slika 2.	Raspored sila na vozilu[17].....	7
Slika 3.	Model ovjesa automobila[17].....	9
Slika 4.	Prikaz pobude sustava[18].....	10
Slika 5.	Informacije o senzoru akceleracije.....	12
Slika 6.	Prikaz pozicioniranja mobitela tokom testiranja	13
Slika 7.	Aleja Bologne.....	14
Slika 8.	Ulica Potok	14
Slika 9.	Bolnička ulica.....	14
Slika 10.	Road Quality prikaz podsustava.....	15
Slika 11.	UML use case Road Quality dijagram	16
Slika 12.	EXPRESS-G, RQ vrijednost segmenta (9.2)	18
Slika 13.	EXPRESS-G, održavanje (9.2)	18
Slika 14.	Razvojno okruženje Eclipse	19
Slika 15.	Logotip	20
Slika 16.	Prikaz zaslona aktivnosti MainActivity i RQActivity.....	21
Slika 17.	Prikaz csv datoteke u Excelu.....	25
Slika 18.	Prikaz RQ vrijednosti na karti (ulica Potok)	27
Slika 19.	Grafički prikaz vrijednosti sa karte (ulica Potok)	27
Slika 20.	Grafički prikaz vrijednosti pomoću maxAccbByLocation	29
Slika 21.	Grafički prikaz vrijednosti pomoću avgJerkByLocation	29
Slika 22.	Usporedba aktivnog i pasivnog ovjesa[17]	30
Slika 23.	Grafički prikaz Citroen Sport mode	31
Slika 24.	Grafički prikaz Citroen Comfort mode	32

POPIS OZNAKA

Oznaka	Jedinica	Opis
accByLocation	m/s^2	zbroj apsolutnih vrijednosti ubrzanja po segmentu ceste
accSqrByLocation	m^2/s^4	zbroj kvadriranih vrijednosti ubrzanja po segmentu ceste
accuracy	m	radijus preciznosti koordinata dobivenih GPS-om
avgAccByLocation	m/s^2	prosječno ubrzanje dobiveno po segmentu ceste
avgAccSqrByLocation	m^2/s^4	prosječno kvadrirano ubrzanje po segmentu ceste
avgJerkByLocation	m/s^3	prosječni trzaj po segmentu ceste
bearing	-	smjer dobiven kompasom
jerk	m/s^3	trzaj
latitude	-	koordinate zemljopisne širine
longitude	-	koordinate zemljopisne dužine
maxAccByLocation	m/s^2	maksimalno ubrzanje po segmentu ceste
maxJerkByLocation	m/s^3	maksimalan trzaj po segmentu ceste
onLocTimeDelta	ms	vremenska razlika između dva mjerenja lokacije
onSensorChangedDelta	ns	vremenska razlika između dva očitavanja vrijednosti akcelerometra
speed	m/s	brzina
totalAccelerationSqr	m/s^2	ukupno ubrzanje po tri osi
totalAccelerationSqr	m^2/s^4	kvadrirana vrijednost ukupnog ubrzanja

SAŽETAK

U okviru ovog rada pokrenuta je SmartCity inicijativa vezana za stanje prometnica na našim cestama. Stanje prometnica u Hrvatskoj je veoma loše stoga je cilj ovog rada da se uz pomoć dostupnih informacijskih i komunikacijskih tehnologija (pametnog telefona) poboljša kvaliteta putnika u vozilima. S tom svrhom izrađena je programska aplikacija imena Road Quality, kojom se uz pomoć GPS prijemnika i senzora akceleracije bilježe udari i vibracije uzrokovani oštećenjima na cestama za specifičnu brzinu vožnje. Na taj način vlasnici automobila i ovlašteni serviseri mogu pratiti stanje i istrošenost sustava ovjesa te sukladno tome planirati servisne intervale. Kako bismo se uvjerali da je sustav izvediv korištenjem pametnog telefona napravljeno je testiranje pomoću dostupnih aplikacija na Google Play Storeu. Nakon provedenog ispitivanja napravljen je model funkcija pomoću toka, UML dijagram aktivnosti i EXPRESS-G modela podataka. Prema tim modelima razvijena je mobilna aplikacija za operativni sustav Android te su izvršena testiranja. Prilikom testiranja utvrđeno je da je sustav dovoljno osjetljiv te sposoban zabilježiti razlike između različito podešenih ovjesa. Kako bismo zabilježili promjene na sustavu ovjesa potrebno je bilježiti vrijednosti u duljem vremenskom razdoblju.

Ključne riječi:

SmartCity, pametni telefon, Gps, senzor akceleracije, RQ vrijednost, cesta, udar, ovjes

1. UVOD

1.1. Smart City

Smart City je pojam koji obuhvaća izrazito širok spektar područja i mogućih rješenja uobičajenih problema gradova. Mnogo je definicija Smart City inicijative ovisno o području u kojem djeluje, od tehničkih rješenja koja utječu na pravila života, električnih vozila do razvoja urbanističkog plana grada [1]. Možemo reći da je Smart City inicijativa koja nastoji prikupiti i obraditi podatke te moguća rješenja u svrhu boljeg i održivog života u gradu. Određena pametna rješenja zahtijevaju promjene koje mogu potrajati nekoliko godina, stoga da bi za grad zaista mogli reći da postaje Smart City potrebna je višegodišnja planirana suradnja gradskih vlasti i stručnjaka, ali i samih građana. Da bi se postigla korist od uvođenja Smart City sustava, nužno je da ljudi imaju dovoljnu razinu edukacije te lako dostupne informacije o primjeni Smart sustava koji ih okružuju kako bi ih mogli u potpunosti iskoristiti.

1.2. Smart City danas

Smart environment uključuje praćenje kvalitete zraka, kvalitetu vode, razinu buke i druge okolišne parametre. Na ovaj način se građanima omogućuje da dobiju informacije o kvaliteti okruženja u kojem žive. Zanimljiv je primjer EkoBus u Beogradu gdje su senzori koji mjere kvalitetu zraka postavljeni na autobuse te tako s manjim brojem senzora (nego kad bi senzori bili stacionarni) mogu pokriti cijelo gradsko područje.

Smart grid je sustav pametne opskrbe električnom energijom koja je ključna stavka za sprečavanje nepotrebnog porasta potrošnje električne energije, a time i ulaganja u nove sustave za proizvodnju električne energije i zagađenja koje ti sustavi donose. On objedinjuje smart meters, tj. sustav pametnog praćenja potrošnje energije, bolju integraciju ekoloških izvora energije, mogućnost pohrane viška energije, mogućnost dvosmjerne komunikacije s kućanskim aparatima te mnoge druge.

Smart buildings su zgrade koje imaju informatičku i senzorsku mrežu koja kontrolira grijanje, hlađenje, ventilaciju, količinu svjetla i druge sustave kako bi postigao što manju potrošnju energenata.

Car Share je sustav koji omogućuje građanima korištenje javno dostupnih automobila unutar grada u bilo kojem trenutku. Potrebno je samo pronaći slobodan automobil ili ga prethodno rezervirati. Ovakav način korištenja automobila smanjuje troškove građana, a

ujedno povećava kvalitetu života u gradu i pojednostavljuje korištenje automobila za osobne potrebe unutar grada.

U Hrvatskoj pa tako i Zagrebu općenito je slaba prisutnost sustava koji bi se zvali pametnima, kao i svijest ljudi o problemima koje bi smart sustavi mogli riješiti. Neki od poznatijih „smart“ projekata su:

- HZZO elektronsko izdavanje recepata za lijekove. Sličan sustav je u postupku uvođenja za veterinarske potrebe
- ZET praćenje vozila, informativni zasloni na stajalištima s prikazom vremena dolaska sljedećeg vozila na pojedinim linijama, sustav elektroničke naplate i kontrole karata
- LIVING LAB kao zajednički projekt (Smart City:Zagreb) Grada Zagreba i Sveučilišta u Zagrebu. Cilj ovog projekta je da postane podloga za rješavanje najvažnijih infrastrukturnih problema grada Zagreba na području energetike i energetske učinkovitosti, javne rasvjete, prometa, urbanizma i graditeljstva, vodoopskrbe i odvodnje te okoliša [2].

1.3. Mobilna tehnologija i Smart City

Preduvjet za razvoj Smart City-a jest određena osnovna razina informacijske povezanosti. To najčešće uključuje sposobnost žičnog i bežičnog informacijskog povezivanja diljem cijelog grada, a poželjna je i veća prisutnost informatičkih sustava, uključujući specijaliziranih senzora. Sama povezanost ne čini Smart City, treba biti prisutna i „pametna“ (ili „smart“) podloga kao dio informatičke strukture grada.

Već iz naziva „pametni“ mobitel ili „smartphone“ možemo zaključiti da se radi o uređaju koji je dio nekog Smart sustava. Sve veća zastupljenost pametnih uređaja daje mogućnost građanima pristup pametnim rješenjima, ali im i omogućuje da se jednostavnije uključe u sam razvoj inicijative. Uz otvorenost mobilnih operacijskih sustava te pristupačnost pametnih uređaja, a sve uz minimalna ulaganja građani se sve više upuštaju u realizacije svojih ideja i time postaju dio Smart City inicijative. Važna uloga, ali i nagli rast popularnosti pametnih mobitela prepoznata je u mnogim granama tehnike pa tako danas imamo pametne: fotoaparate, televizore, kućanske aparate itd.

Popularnost Android OS-a i iOS-a odrazila se na automobilsku industriju pa tako danas sve više proizvođača nudi mogućnost povezivanja pametnih telefona s automobilom. Trenutno jedan od boljih primjera je CarPlay napravljen usuradnji: Apple-a, Ferrari-a, Mercedes-a, Honde, Volva i Hyundai-a, a najavljena je i suradnja s mnogim drugim proizvođačima. CarPlay nudi potpunu sinkronizaciju pametnog telefona s automobilom uz prikaz mogućnosti na ekranu vozila, što omogućuje korištenje pametnog telefona uz neometano upravljanje automobila.

1.4. Stanje prometnica u Republici Hrvatskoj

Stanje prometnica u Hrvatskoj prema osobnom iskustvu u usporedbi s ostalim članicama EU je ispod prosjeka, rezultat je to provedbe neplanskih radova i popravaka na cestama. Često smo svjedoci da se u ulici postavi novi asfalt te nakon manje od mjesec dana ulica se prekopava zbog nekog od kućnih priključaka. Velik problem zasigurno je i kvaliteta izrada samih prometnica ovisno kategoriji vozila koje prometuju kao i često „krpanje“ oštećenja. Takav pristup održavanju i izradi prometnica dovodi do stanja prometnica sa puno neravnina, izbočina, kolotraga i rupa, a vožnja do po takvim prometnicama uvelike utječe na stanje naših automobila. Osim relativno lošeg stanja prometnica velik problem predstavljaju tzv. ležeći policajci. Broj postavljenih ležećih policajaca vjerojatno je veći od potrebnog, a nerijetko su veći od dopuštenih dimenzija.

Program građenja i održavanja cesta za razdoblje 2013.-2016, na temelju analize za 2013. godinu dao je opću ocjenu stanja kolnika mreže državnih cesta. Tvrdi se da je trećina u dobrom stanju i još dodatnih 43% u zadovoljavajućem. S druge strane, oko 25% je u lošem i vrlo lošem stanju. Ocjena udobnosti kolnika (utjecaj ravnosti, kolotraga, oštećenja i ispucanosti kolnika na udobnost putovanja) donosi još poraznije rezultate. Čak 38% državnih cesta je na tom polju ocijenjeno lošim i vrlo lošim[4]. Internet anketu proveo je Hrvatski autoklub (HAK) na 954 sudionika o stanju lokalnih prometnica. Čak 72% ispitanih ocjenjuje prometnice lošim i vrlo lošim, po pitanju brojnosti udarnih rupa 83% ispitanika ocijenilo kao loše i vrlo loše [4].

2. ROAD QUALITY SUSTAV

2.1. Oštećenja na ovjesu automobila

Uzmemo li u obzir kako je stanje prometnica na području Hrvatske ispod prosjeka, to nas dovodi do zaključka da konstrukcijski zahtjevi ovjesa automobila ne odgovaraju prosječnim zahtjevima europskog korisnika. Često smo svjedoci velikih troškova popravka automobila s obrazloženjem: „sve je to zbog loših cesta“. Razgovorom s nekoliko ovlaštenih servisa u Zagrebu (Peugeot, Mercedes) dobio sam informaciju kako su dijelovi koji se najčešće oštećuju zbog loših prometnica: krajnici spona, kugle, letva volana i amortizeri. Na primjer kod modela Peugeot 407 kugle je potrebno mijenjati svakih godinu do dvije.

2.2. Utjecaj oštećenih prometnica na udobnost vožnje

Prometnica kojom se automobil kreće direktno određuje razinu udobnosti odnosno neudobnosti. Kako bi se razina udobnosti povećala osmišljen je adaptivni ovjes, tj. ovjes s mogućnošću podešavanja prigušnih i reaktivnih sila. Većina automobila nudi korisniku mogućnost odabira nekoliko profila vožnje, kao što su sport i comfort. Takav pristup često ne može pratiti dinamiku promjena uvjeta na cesti te je potrebno rješenje koje bi unaprijed reagiralo i prilagođavalo ovjes.

Koliko je udobnost bitan faktor pokazuje nam sve veći razvoj različitih sustava za udobnost vožnje. Jedan od boljih primjera je razvijen od tvrtke Mercedes-Benz pod nazivom „Magic body control“. To je sustav orijentiran na dinamiku vožnje te stanju ceste, a inovativna značajka je njegov podsustav imena „Road surface scan“ za snimanje neravnina na nadolazećoj cesti. Magic body control prilagođuje ovjes ovisno brzini i podacima dobivenih stereo kamerom i senzorom ubrzanja (bočne sile) 0.

2.3. Road Quality rješenja

U okviru Smart City inicijative dakako da ne možemo očekivati popravak i dovođenje svih prometnica na visoku razinu kvalitete, ali možemo promijeniti pristup problemu orijentirajući se na vozila koja se njima kreću. Ukoliko imamo informacije o stanju prometnica otvaraju nam se razne mogućnosti od planiranja same rute kretanja vozilom,

podešavanja ovjesa ovisno o nadolazećem stanju prometnice pa čak i do boljeg definiranja konstrukcijskih i servisnih zahtjeva automobila ovisno o regionalnoj sredini.

Road Quality sustav zamišljen je kao sustav koji bi pomoću pametnog mobilnog telefona te ugrađenih senzora i GPS prijamnika bilježio udare i vibracije ovisno o specifičnoj brzini tokom vožnje. Ti podaci bilježili bi se na karti te bi ih se oni mogli iskoristiti kao informacije za prilagođavanje ovjesa vozila, ali i usporedbu te procjenu stanja sustava ovjesa.

2.3.1. Primjena u svrhu prilagodbe ovjesa automobila

Razinu udobnosti možemo definirati kao odnos veličina vertikalnih sila u automobilu i prijeđenog puta. Prolaskom vozila po prometnici možemo pomoću pametnog mobitela zabilježiti ubrzanja i trzaje u automobilu uzrokovana neravninama. Zabilježimo li ubrzanja u smjeru vertikalne osi, dobit ćemo podatke koji određuju razinu udobnosti ovisnoj o brzini kretanja vozila. Dodamo li tim podacima zemljopisne koordinate možemo napraviti kartu koja nam prikazuje informacije o stanju ceste. Takvu kartu možemo iskoristiti za planiranje optimalne rute u smislu udobnosti vožnje. Povežemo li takvu kartu sa sve češćim pametnim sustavima u automobilu, dovodimo informacije za prilagodbu ovjesa automobila ovisno stanju nadolazeće ceste te povećavamo razinu udobnosti u vožnji.

2.3.2. Primjena u svrhu praćenja utjecaja na oštećenje sustava ovjesa automobila

Prelaskom vozila preko oštećenog dijela prometnice rezultira se oštećenjima na sustavu ovjesa automobila. Učestalom vožnjom po cestama lošeg stanja dolazi do skraćivanja „životnog vijeka“ pojedinih dijelova te zamjetnog pada razine udobnosti vožnje. Trenutno stanje sustava ovjesa može se utvrditi pomoću nekoliko metoda ispitivanja 0:

- Provjera uređajem za ispitivanjem podvozja, tzv. shock tester (Slika 1.)
- Određivanje prigušnih i reaktivnih sila specijalnim uređajima na prethodno izvađenim dijelovima
- Usporedba s novim vozilom istog tipa
- Vizualna provjera


Road Quality omogućuje ovlaštenim serviserima, proizvođačima ali i svim vlasnicima automobila da prate ponašanje sustava ovjesa automobila u određenom vremenskom razdoblju. Vlasnici automobila imaju stalan uvid u trenutno stanje njihovog automobila usporedbom prethodno dobivenih rezultata s trenutnim izmjerenim. Na taj način vlasnici automobila mogu preventivno reagirati ukoliko dođe do značajnog odstupanja rezultata s rezultatima novog automobila ili njihovog referentnog zapisa. Ovlašteni serviseri mogu prati ponašanje sustava ovjesa kroz dulji vremenski period te sukladno rezultatima vršiti naknadne metode ispitivanja te procjenjivati potrebne servisne intervale. Proizvođači automobila i dijelova imaju mogućnost usporedbe rezultata ponašanja ovjesa pri specifičnim brzinama te sukladno tome raditi izmjene u sustavu ovjesa. Također proizvođači mogu uspoređivati ponašanje sustava ovjesa u različitim regijama te na temelju toga definirati zahtjeve za određena konstrukcijska rješenja i održavanje specifična toj regiji.



Slika 1. Uređaj za ispitivanje podvozja 0

3. DINAMIKA VOZILA

Dinamiku vozila možemo podijeliti u dva različito promatrana sustava, onu koja se odnosi na karoseriju automobila s pripadajućim ovjesom i dinamiku pogonskog dijela vozila. Na dinamiku vozila (karoserija, ovjes) utječu :sile na gumama, zemljina sila teža, otpor zraka te otpor kotrljanja, dok na dinamiku pogonskog dijela vozila utječu: pogonski motor, sustav prijenosa snage s motora na kotače te kočioni sustav[17]. U okviru ovog rada razmatrat ćemo dinamiku vozila u pogledu sustava ovjesa. Raspored sila koje djeluju na vozilo prikazano je slikom (Slika 2).



Slika 2. Raspored sila na vozilu[17]

Svaka istrošenost ili oštećenje sustava ovjesa vozila rezultira različitim rasporedom sila na kotačima što pridonosi smanjenju voznih karakteristika automobila.

Gdje je:

- F_{zf} vertikalna (normalna) sila na prednjim kotačima
- F_{xf} uzdužna sila na prednjim kotačima
- F_{zr} vertikalna (normalna) sila na stražnjim kotačima
- F_{xr} uzdužna sila na stražnjim kotačima
- R_{xr} sila otpora kotrljanja na stražnjim kotačima
- R_{xf} sila otpora kotrljanja na prednjim kotačima
- F_{aero} sila otpora zraka
- m masa vozila
- g ubrzanje zemljine sile teže
- $m\ddot{x}$ sila inercije vozila

Postavljanjem suma sila po vertikalnoj osi dobivamo izraze (3.1) i (3.2) za izračun sila u prednjim i stražnjim kotačima (gumama):

$$F_{zf} = \frac{-F_{aero} \cdot h_{aero} - m\ddot{x}h - mgh \cdot \sin \theta + mgl_r \cdot \cos \theta}{l_f + l_r} \quad (3.1)$$


$$F_{zr} = \frac{F_{aero} \cdot h_{aero} + m\ddot{x}h + mgh \cdot \sin \theta + mgl_f \cdot \cos \theta}{l_f + l_r} \quad (3.2)$$

3.1. Ovjes automobila

Sustav ovjesa automobila s obzirom na njegovu dinamiku možemo podijeliti na tri vrste: pasivni, aktivni i polu-aktivni [17]. Aktivni ovjes za razliku od pasivnog sadrži senzore i pogone za prilagodbu ovjesa, dok polu-aktivni ima mogućnost promjenu veličine prigušenja. Idealan ovjes automobila bio bi mekan za udobnost u vožnji, a tvrd za postizanje boljih voznih karakteristika. Postizanje takvih karakteristika zadaća je aktivnog ovjesa.

Kako bismo opisali što se događa s ovjesom automobila nailaskom na neravninu promatrat ćemo kotač automobila s pripadajućom vilicom i amortizerom kao zaseban sustav. Takav sustav (Slika 3.) možemo prikazati pomoću MDS modela sustava te njegovo ponašanje opisati diferencijalnim jednadžbama.

- k_s konstanta opruge amortizera
- b_s prigušenje
- F_a aktivna sila
- m_s masa vozila
- m_u masa kotača vozila
- k_t konstanta krutosti gume
- Z_s vertikalni pomak karoserije vozila
- Z_u vertikalni pomak kotača vozila
- Z_r vertikalni pomak na gumi zbog neravnine na cesti



Slika 3. Model ovjesa automobila[17]

Model se sastoji od klasičnih dijelova MDS sustava: opruge, prigušenja, mase i opterećenja (sile), a njegova dinamika praćena je pomacima (Z) po vertikalnoj osi.


Sila F_a predstavlja veličinu koja je rezultat rada aktivnog ovjesa, tj. toliku silu je potrebno ostvariti da bi se poništile povećane sile uzrokovane neravninama na cesti. Kod pasivnog ovjesa aktivna sila $F_a=0$, ali je za ovaj rad upravo ona zanimljiva jer njen iznos prikazuje utjecaj na udobnost u vožnji te povećanje sila na sustav ovjesa. Dođe li do oštećenja na ovjesu automobila povećat će se vrijednost potrebne sile F_a . Kako u okviru ovog rada mjerimo vrijednosti pomoću pametnog telefona smještenog na armaturi vozila, senzor ubrzanja izračunava vrijednosti na temelju vertikalnog pomaka Z_s koji je u izravnoj vezi s vertikalnim pomakom kotača Z_u i vertikalnim pomakom Z_r uslijed neravnine na cesti.

Izraz za aktivnu silu u diferencijalnom obliku glasi [17]:

$$F_a = m_s \ddot{Z}_s + b_s (\dot{Z}_s - \dot{Z}_u) + k_s (Z_s - Z_u) \quad (3.1.1)$$

$$-F_a = m_u \ddot{Z}_u + b_t (\dot{Z}_u - \dot{Z}_r) + k_t (Z_u - Z_r) - b_s (\dot{Z}_s - \dot{Z}_u) - k_s (Z_s - Z_u) \quad (3.1.2)$$

Kako bismo grafički opisali ponašanje automobila nailaskom na neravninu pomoću MDS sustava, neravnine na cesti su zamijenjene „step“ (Heavisideovom) funkcijom te je prikazan grafički rezultat sila i pomaka karoserije (Slika 4)[18].



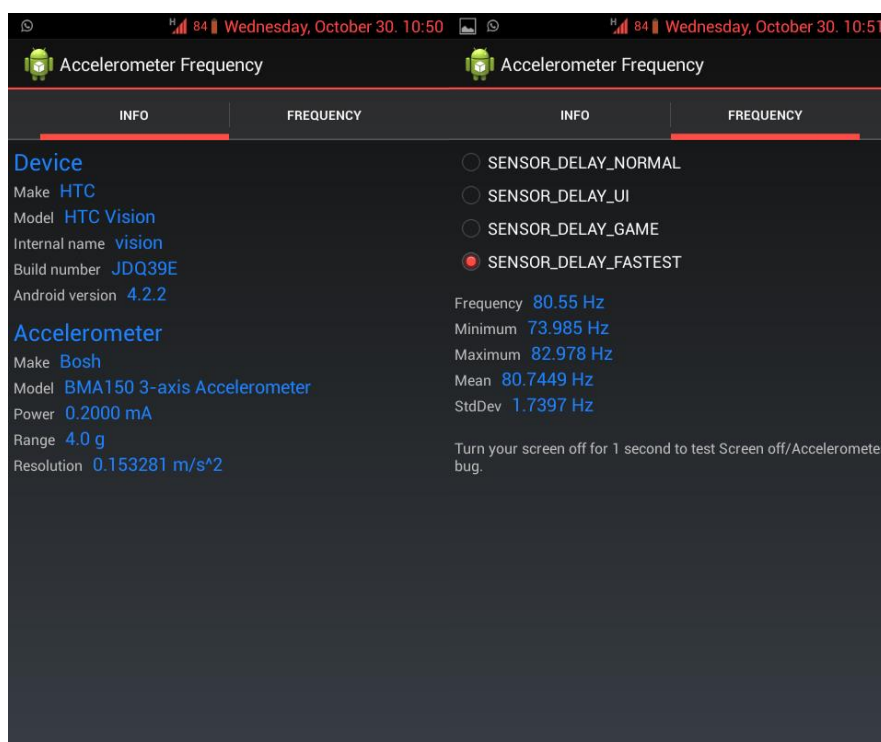
Slika 4. Prikaz pobude sustava[18]

Promjena parametara vozila b_s i k_s rezultira različitim ponašanjem sustava ovjesa pri specifičnim brzinama[17]. Dođe li do oštećenja opruga amortizera rezultirat će se smanjenjem krutosti opruge k_s te će se to kao posljedica odraziti na povećanje pomaka ovjesa ($Z_u + Z_s$) pri nižim frekvencijama. Ošteti li se prigušni dio amortizera to će se rezultirat potrebnim dužim vremenskim razdobljem da se sustav nakon pobude (neravnine na cesti) vrati u stanje ravnoteže. Oštećenjem nosivih dijelova kao što su vilice rezultirat će naglim skokovima vertikalnih sila u vozilu te izraženijim pomakom karoserije automobila.

Svaka istrošenost ili oštećenost sustava ovjesa vozila rezultira različitim rasporedom sila na kotačima što pridonosi smanjenju voznih karakteristika automobila.

4. UTVRĐIVANJE MOGUĆNOSTI RAZVOJA ROAD QUALITY SUSTAVA

Kako bi se utvrdilo da li postoji tehnička podloga za razvoj Road Quality sustava napravljeno je istraživanje pomoću dostupnih aplikacija u Google Play trgovini. Uređaj korišten u ovom istraživanju je pametni telefon HTC Desire Z. Korištene su dvije aplikacije, Accelerometer Frequency [7] i Sensor Logger [8]. Aplikacijom Accelerometer Frequency utvrđeno je da se u testnom uređaju nalazi tro-osni senzor akceleracije tipa Bosh BMA150, mjerne rezolucije $0,153281 \text{ m/s}^2$, raspona mjerenja od 4,0 g, maksimalne frekvencije 80 Hz s mogućnošću postavljanja različitog vremena kašnjenja (Slika 5.).



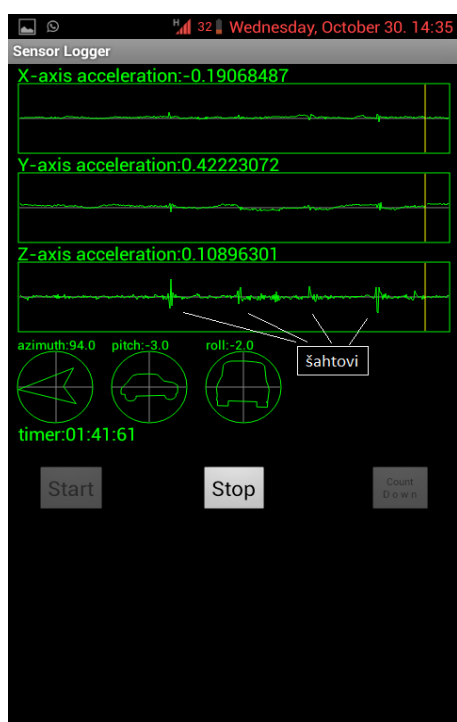
Slika 5. Informacije o senzoru akceleracije

Druga korištena aplikacija imena Sensor Logger omogućuje prikaz ubrzanja na dijagramima po tri osi (x, y, z) u ovisnosti o vremenu. Pomoću te aplikacije napravljen je zapis tokom vožnje s kojim je utvrđeno da senzor može zabilježiti dovoljno brzo različite visine neravnine na cesti s zadovoljavajućom osjetljivošću. Mobilni uređaj tokom testiranja bio je postavljen na kontrolnu ploču automobila pomoću ljepljive podloške (Slika 6.), te su napravljene preslike zaslona.



Slika 6. Prikaz pozicioniranja mobitela tokom testiranja

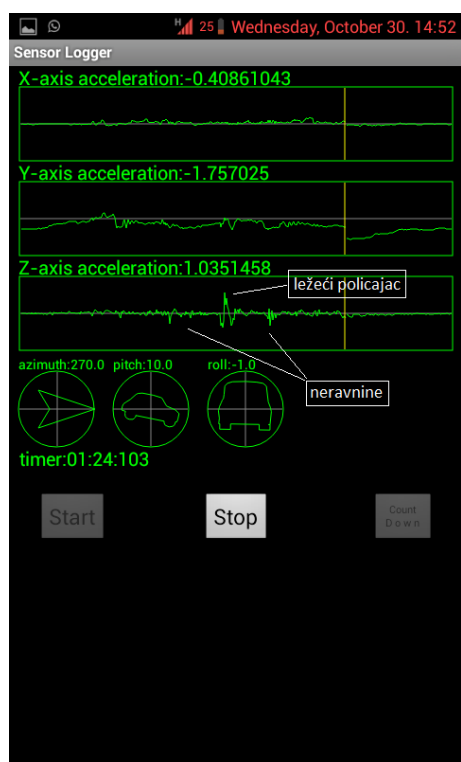
Kao primjer dobre ceste s nekoliko šahtova odabrana je Aleja Bologne gdje se može vidjeti mala promjena ubrzanja po z osi ($\pm 3 \text{ m/s}^2$) nailaskom vozila na šaht (Slika 7.). Za primjer vožnje po lošoj cesti uzeta je Ulica Potok te se na Slici 8. jasno vidi velika ($\pm 10 \text{ m/s}^2$) promjena ubrzanja u kratkom vremenskom periodu. Da prelazak preko ležećih policajaca djeluje slično kao i prelazak preko oštećenja na cesti samo sa dužom vremenskom oscilacijom zabilježeno je u Bolničkoj ulici (Slika 9.).



Slika 7. Aleja Bologne



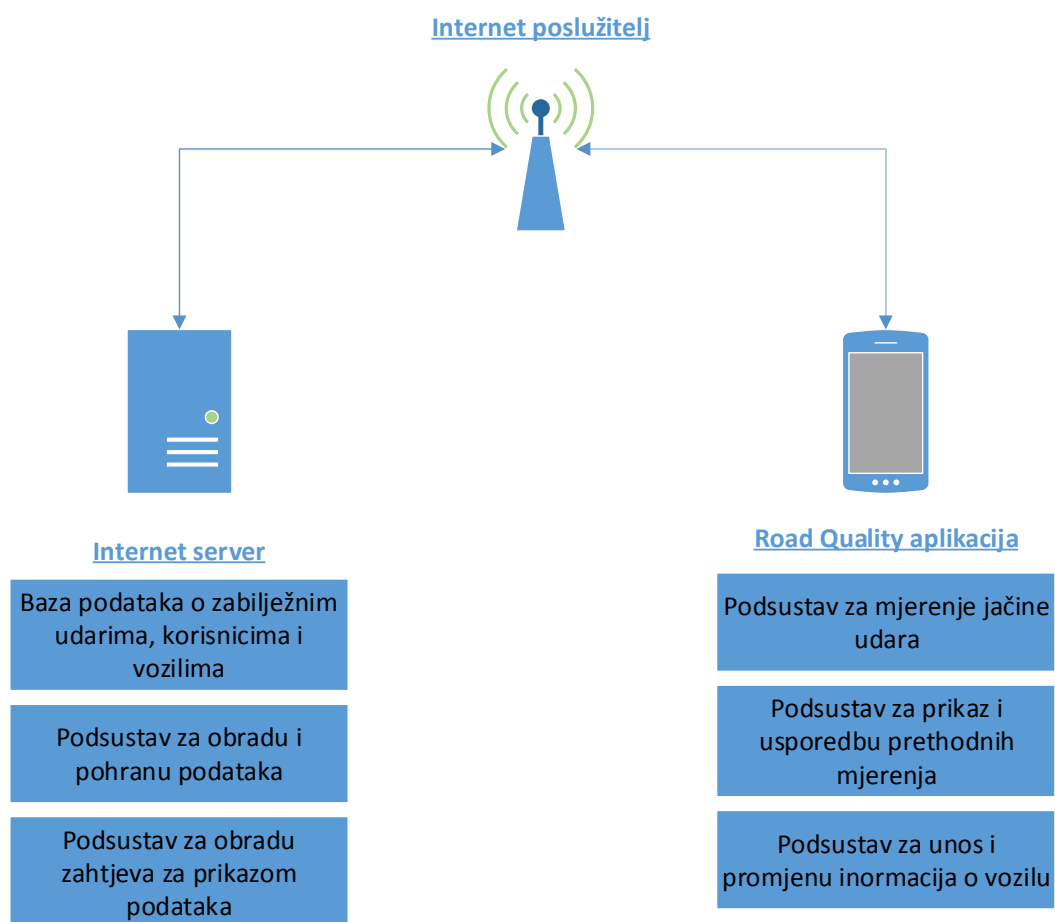
Slika 8. Ulica Potok



Slika 9. Bolnička ulica

5. MODEL PODATAKA I DIJAGRAM FUNKCIJA ZA SUSTAV ZA PRAĆENJE UDOBNOSTI VOŽNJE

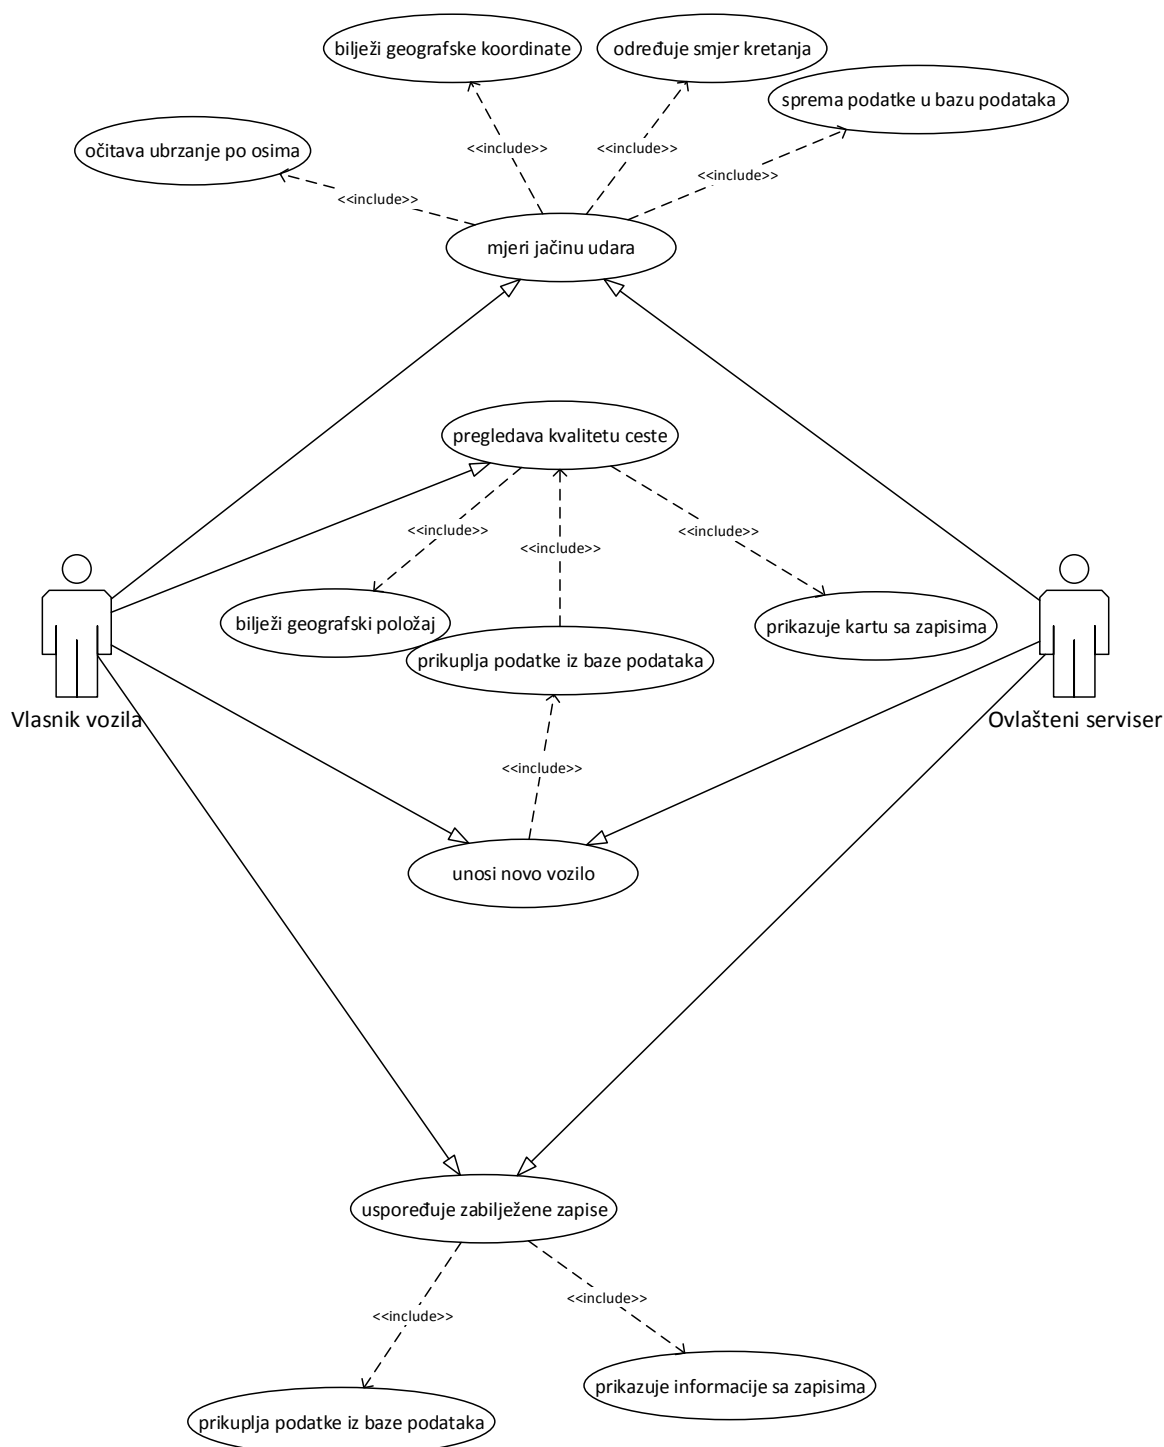
Kao alat za razvoj modela sustava te potrebne aplikacije korišteni su model funkcija pomoću toka, UML use case dijagram, UML dijagram aktivnosti i EXPRESS-G model podataka. Svi dijagrami nalaze se u prilogu. Na slici 10. je prikazana interakcija korisnika (vlasnika automobila, ovlaštenih serviser) sa sustavom koji se sastoji od aplikacije za pametni telefon i internetskog servera. Aplikacija korisnicima omogućuje mjerenje, zapis i prikaz podataka o jačini udara, dok se na internetski server spremaju obrađeni zapisi o udarima.



Slika 10. Road Quality prikaz podsustava

Uml use case dijagram opisuje ponašanje sustava iz perspektive vanjskog korisnika, tj. tko može činiti što u sustavu [9]. UML use case dijagram odnosno dijagram uporabe prikazan je na slici 11., a UML dijagram aktivnosti nalazi se u prilogu (UML dijagram aktivnosti).

Road Quality UML use case



Slika 11. UML use case Road Quality dijagram

5.1. Modeliranje funkcija pomoću toka za Road Quality sustav

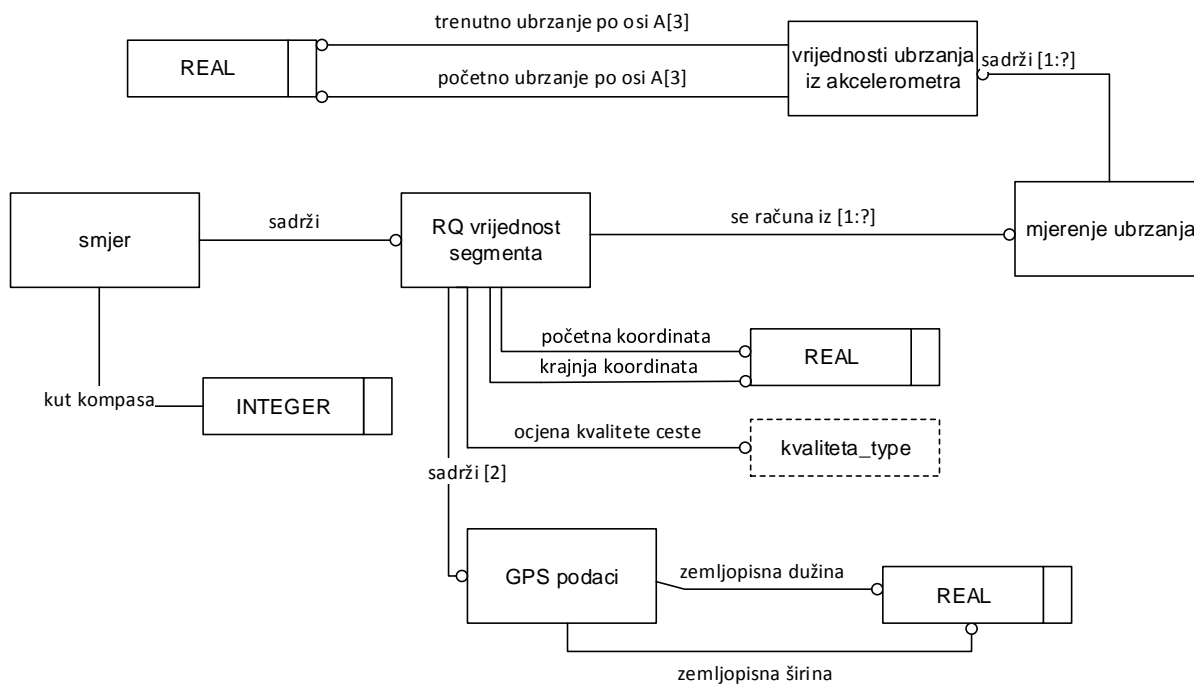
Pod pojmom funkcija podrazumijeva se neutralna (obzirom na tehničko rješenje) formulacija predviđene svrhe promatranog proizvoda. Funkcijski model zasnovan na toku prikazuje promjenu karakteristika operanda u operaciji [10].

Korištenje Road Quality sustava započinje otvaranjem mobilne aplikacije, korisnik se prijavljuje u sustav ukoliko je prethodno obavio registraciju. Nakon prijave korisniku je omogućeno da odabere želi li izabrati postojeće registrirano vozilo u sustavu, unijeti novo ili mijenjati postavke profila i aplikacije. Ukoliko je odabrano postojeće vozilo moguće je promijeniti informacije o vozilu kao što su tlak u gumama, broj putnika, dimenzije guma, razina spremnika goriva. Nakon odabira vozila prikazuje se karta s trenutnom lokacijom određenom putem GPS-a te je ponuđen odabir prikaza vlastitih ili ukupnih Road Quality informacija. Nakon prikaza željenih informacija korisnik se počinje kretati automobilom i započinje s bilježenjem brzine, ubrzanja po vertikalnoj osi i geolokacije. Završetkom mjerenja korisnik ima mogućnost usporedbe zabilježenih rezultata s prethodno izmjerenim te svoje mjerenje sprema u bazu podataka. Cjelokupan prikaz modela funkcija pomoću toka nalazi se u prilogu (Model funkcija sustava pomoću toka).

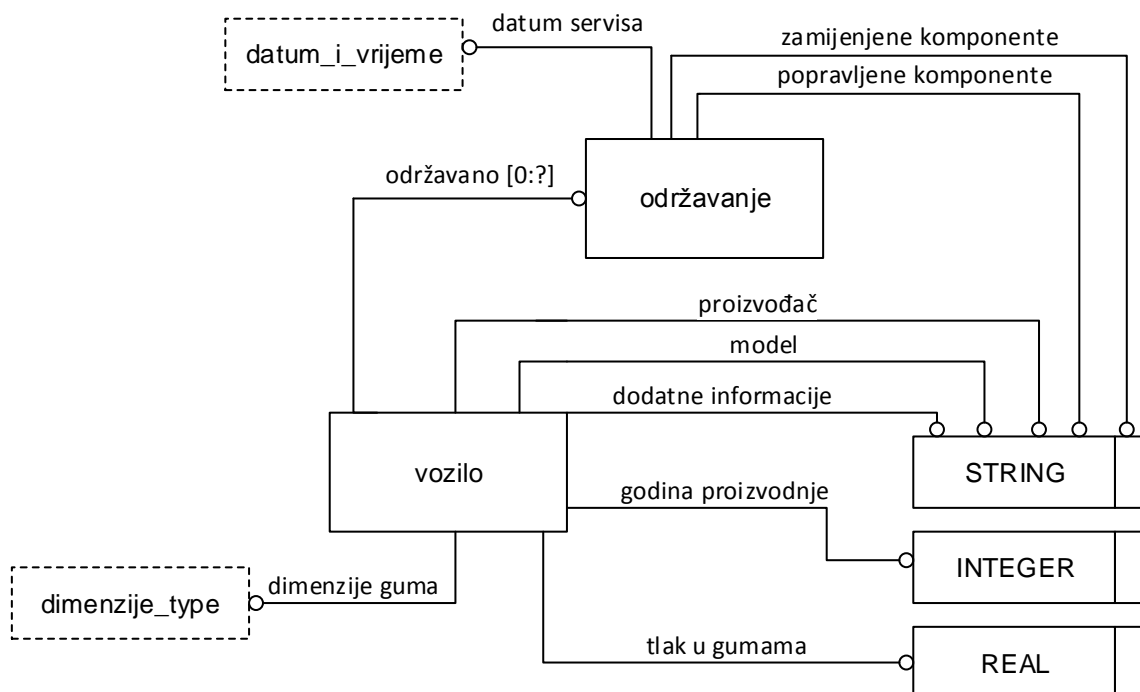
5.2. Model podataka

Za izradu modela podataka korišten je EXPRESS G (EXPRESS-G dijagram podataka), to je grafički jezik za modeliranje informacija temeljen na entity-relationship modelu podataka. Zasnovan je na standardnom EXPRESS jeziku koji je dio međunarodnog ISO 10303-11 standarda [10].

Supertip ovog modela je član sustava, tj. korisnik. Član može bit vlasnik vozila ili ovlašteni serviser (subtip). Najvažniji entitet ovog sustava je RQ vrijednost segmenta (Slika 12.), on sadržava ocjene jačine udara kao rezultata ubrzanja po vertikalnoj osi između dvaju segmenta ceste. Segmenti su određeni zemljopisnim koordinatama, brzinom te smjerom, a ovise o brzini senzora. Uz podatke koji se unose pri unosu novog vozila moguće je i upisivati podatke o održavanju vozila (Slika 13.). Entitet održavanje služi nam za usporedbu i praćenje stanja sustava ovjesa vozila.



Slika 12. EXPRESS-G, RQ vrijednost segmenta (10.2)




Slika 13. EXPRESS-G, održavanje (10.2)

6. RAZVOJ ROAD QUALITY APLIKACIJE


6.1. Operativni sustav i razvojno okruženje

Za razvoj aplikacije odabran je operativni sustav Android. Korišteni su pametni telefoni LG Nexus 4 s Android verzijom 4.4.2 i HTC Desire Z s Android verzijom 4.2.2. Razvojno okruženje odabrano je Eclipse Standard verzija 4.3.1 [11]. Za rad s Androidom Eclipseu je dodan Android Developer Tools plugin i Android Software development kit [12]. Računalo potrebno za rad korišteno je s operativnim sustavom Windows 8. Programski kod aplikacije pisan je u Java programskom jeziku[35] dok je korisničko sučelje definirano XML datotekama.



Slika 14. Razvojno okruženje Eclipse

Aplikacija je nazvana „Road Quality“, minimalna podržana verzija Android OS-a za korištenje je Ice Cream Sandwich 4.0.3. Sukladno imenu napravljen je i Logotip u programu LogoMaker[13](Slika 15).



Slika 15. Logotip

6.2. Road Quality aktivnosti

Aktivnost (Activity) kod Android OS-a predstavlja zaseban zaslon s određenim funkcijama, a svaka je aplikacija izrađena od jedne ili više aktivnosti. Kod pokretanja aplikacije pokreće se MainActivity (Slika 16.) te se iz nje dalje pokreću druge aktivnosti. Trenutna verzija aplikacije Road Quality sastoji se od četiri aktivnosti. Aktivnost u kojoj se odvija mjerenje jačine udara nazvana je RQActivity, SettingsActivity služi za promjenu postavki aplikacije, dok NewVehicleActivity omogućuje unos novog vozila.



Slika 16. Prikaz zaslona aktivnosti MainActivity i RQActivity

6.2.1. Aktivnost RQActivity

U ovoj aktivnosti odvijaju se najvažnije funkcije za rad aplikacije, prikazuju se vrijednosti sa senzora te je omogućena njihova pohrana. Kako bi se ostvario rad planiranih funkcija upotrijebljeno je nekoliko aplikacijskih programskih sučelja (application programming interface-API). API je skup određenih pravila i specifikacija koje programeri slijede tako da se mogu služiti uslugama ili resursima [35].

Google Location Services API omogućuje dobivanje vrijednosti kao što su brzina, nadmorska visina, geografska širina i dužina te preciznost dobivene lokacije. Sensor API služi za dobivanje vrijednosti iz senzora ugrađenih u pametni telefon (senzor temperature, barometar akcelerometar, žiroskop, kompas i drugi). Kako bi se očitavanja sa senzora zapisala u csv datoteku i spremila u memoriju mobitela korišten je File i FileWriter (API). Senzore i memoriju nije moguće koristiti bez definiranih dopuštenja, stoga je uneseno dopuštenje za korištenjem GPS podataka: *android.permission.ACCESS_FINE_LOCATION* i dopuštenje za zapisivanje datoteka u memoriju: *android.permission.WRITE_EXTERNAL_STORAGE*.

Pokretanjem RQActivity aktivnosti pokreću se *onCreate* i *onStart* metode čime se pozivaju senzor akceleracije i kompas te se definiraju njihove *SENSOR_DELAY* vrijednosti tj. vrijednosti kašnjenja. Za akcelerometar je bitno da ta vrijednost bude što veća stoga je postavljena na *SENSOR_DELAY_FASTEST* kako bi senzor bilježio vrijednosti s maksimalnom frekvencijom, dok kod kompasa je dovoljno postaviti vrijednost na *SENSOR_DELAY_NORMAL*. Također se poziva *LocationManager* koji služi za očitavanje vrijednosti lokacije uređaja. Zbog važnosti točnosti određivanja lokacije poziva se *requestLocationUpdates* te se davatelj informacija postavlja na *GPS_PROVIDER*, kako bi se za određivanje lokacija koristili podatci dobivani GPS-om. Druga varijabla u *requestLocationUpdates* metodi određuje kašnjenje između zahtjeva za lokacijom, dok je treća vrijednost razlika u metrima između dviju lokacija koja je određena na 2 m kako se ne bi bilježili podatci dok vozilo stoji.

```
LocationManager locationManager = (LocationManager)
getSystemService(Context.LOCATION_SERVICE);

locationManager.requestLocationUpdates(LocationManager.GPS_PROVIDER
, 0, (float) 2.0, this);
```

6.2.1.1. onSensorChange metoda

Kod svake promjene vrijednosti senzora poziva se *onSensorChanged* metoda, za testni uređaj LG Nexus 4 maksimalna promjena vrijednosti je frekvencije 200 Hz. Unutar ove metode očitavaju se vrijednosti ubrzanja po osima i vrijednost kompasa. Za mjerenje jačine udara koristit će se nekoliko varijabli, zbog utjecaja nagiba vozila, telefona te samog kretanja vozila. Prva varijabla nazvana je *totalAcceleration* koja se zbog pretpostavljenog mjerenog ubrzanja po vertikalnoj-z osi, a uslijed prisutnog ubrzanja po y i x osi zbog nagiba vozila i pametnog telefona na komandnoj ploči računa pomoću izraza:

```
totalAcceleration =
((Math.sqrt(Math.pow(yAcc,2)+Math.pow(zAcc,2)+Math.pow(xAcc, 2))-10));
```

Od vrijednosti izmjerenog ubrzanja oduzima se vrijednost 10 m/s^2 koja predstavlja gravitacijsko ubrzanje, a određena je kao gravitacijsko ubrzanje koje bilježi uređaj LG Nexus 4.

Druga varijabla *totalAccelerationSqr* uvedena je kao svojevrsan filter za uklanjanje odstupanja od ubrzanja ovisno o položaju pametnog telefona na komandnoj ploči +/- 0.4 m/s² te šuma senzora 0.3 m/s². Kvadriranjem prve varijable dodatno se umanjuje pogreška.

```
totalAccelerationSqr = Math.pow(totalAcceleration, 2);
```

Treća varijabla *jerk* uvedena je zbog pojave značajnog ubrzanja kod vožnje cestom s velikim nagibom, takvo ubrzanje nema utjecaja na ovjes automobila ukoliko je u smjeru gibanja automobila. Varijabla *jerk* predstavlja trzaj te na njega kao varijablu značajno ne utječe ubrzanje samog automobila. Razlika u vremenu kod promjene akceleracije bilježi se u nanosekundama stoga je varijablu ubrzanja potrebno pomnožiti sa 10⁶ kako bi se dobili m/s².

```
onSensorChangedDelta = onSensorChangedNewTime-  
onSensorChangedOldTime;  
  
jerk=((totalAcceleration-totalAccelerationOld)  
/(onSensorChangedDelta))*1000000000;
```

Nailaskom automobila na neravninu senzor bilježi pozitivne i negativne vrijednosti, tj. vrijednosti u oba smjera vertikalne osi. Kako bismo odredili prosječne vrijednosti akceleracije, kvadrata akceleracije i trzaja, računat ćemo s njihovim apsolutnim vrijednostima. Unutar jednog segmenta ceste određuje se prosječna vrijednost te na temelju toga vršna vrijednost segmenta.

```
accByLocation = accByLocation + Math.abs(totalAcceleration);  
accSqrByLocation = accSqrByLocation +  
Math.abs(totalAccelerationSqr);  
jerkByLocation = jerkByLocation + Math.abs(jerk);  
  
if (Math.abs(totalAcceleration)>maxAccByLocation){  
    maxAccByLocation=Math.abs(totalAcceleration); }  
  
if (Math.abs(jerk)>maxJerkByLocation){  
    maxJerkByLocation=Math.abs(jerk); }
```

Unutar ove metode određuje se smjer gibanja koji se pohranjuje u varijablu *bearing* te se svakim pokretanjem metode povećava za 1 vrijednost varijable *runCounter* koja bilježi broj mjerenja akceleracija po segmentu, a koristi se za izračun prosječnih vrijednosti akceleracije i

trzaja. Prosječne vrijednosti zapisane su u varijablama kao *avgAccByLocation* (m/s^2), *avgAccSqrByLocation* (m^2/s^4) i *avgJerkByLocation* (m/s^3).

6.2.1.2. onLocationChange metoda

Kako bismo zabilježili niz RQ segmenata duž prometnice potrebna nam je metoda koja će bilježiti zapise zavisno o promjeni lokacije, *onLocationChanged* metoda. Unutar ove metode pozivaju se *File* i *FileWriter* koje zapisuju vrijednosti varijabla te se prikazuju unutar *TextView* objekata. Uvodimo nove varijable: *time* (ms)-trenutno vrijeme, *onLocTimeDelta* (ms)-razlika vremena između dvije lokacije te ih zajedno s ranije navedenim prosječnim vrijednostima zapisujemo u *csv* datoteku:

```
File record = new File(filename);
FileWriter writer = null;
writer = new FileWriter(record, true);

time = System.currentTimeMillis()-startTime;
onLocTimeDelta = System.currentTimeMillis() -
lastOnLocChangedTime;

avgAccByLocation = (accByLocation/(runCounter));
avgAccSqrByLocation = (accSqrByLocation/(runCounter));

avgJerkByLocation = (jerkByLocation/(runCounter));
```

```
TextView textView19=(TextView) findViewById(R.id.textView19);
textView23.setText(String.format("%.0f", accuracy));
```

Zapis vrijednosti u *csv* datoteku osmišljen je pomoću vektora stringova *csvLine*, gdje je za svaku varijablu određen broj decimalnih mjesta naredbom *String.format*:

```
csvLine[3] = String.format("%.0f", accuracy);
```

Kako bi smo započeli mjerenje potrebno je pritisnuti gumb *Start*, tada boolean varijabla *startcsv* poprima vrijednost *true*. Zapis naziva svih varijabla vrši se u prvom redu te se svaka nova vrijednost varijable upisuje ispod njenog naziva pomoću *csvLine* vektora. Izgleda *csv* datoteke prikazan je tablicom pomoću Excel-a (Slika 17.).

time	latitude	longitude	accuracy	bearing	speed	onLocTimeDelta	
10089	45,94388	15,80981	22	163	0,2500	1007	
12096	45,94391	15,80974	12	166	0,0000	2000	
13099	45,94378	15,8097	17	166	0,5000	997	
14087	45,9437	15,80978	24	167	1,1189	996	
avgAccByLocation		maxAccByLocation		avgAccSqrByLocation		avgJerkByLocation	maxJerkByLocation
0,2555		0,3620		0,0670		36,8375	317,6303
0,2635		0,4934		0,0743		37,9769	312,1344
0,2604		0,4063		0,0711		45,7807	318,6785
0,2649		0,3666		0,0717		36,8744	306,5126

Slika 17. Prikaz csv datoteke u Excelu


7. REZULTATI TESTIRANJA ROAD QUALITY SUSTAVA

U fazi testiranja mobilne aplikacije korištena su dva automobila, Toyota Yaris i Citroen C5. Testiranjem na različitim automobilima možemo napraviti usporedbu udobnosti automobila, ali i zabilježiti ponašanje prilikom različitih modova vožnje. Da bi smo pravilno usporedili istrošenost ovjesa automobila potrebno je napraviti testiranje i na novim automobilima kako bismo dobili referentne vrijednosti. U vrijeme izrade ovog rada nisam imao pristup novim automobilima ova dva tipa te je to planirano za kasniji razvoj. Rezultati mjerenja prikazani su pomoću web servisa GPSVizualizer [16] u obliku karte s iscrtanim vrijednostima te popratnim grafovima. Na karti su iscrtane vrijednosti u obliku obojenih linija, gdje zelena boja označava najmanje RQ vrijednosti, a crvena najveće. Kao vrijednost za najpregledniji prikaz prikazao se avgJerk (prosječan trzaj), zbog toga što najviše ističe nagle promjene vibracija i razinu udara te na njega značajno ne utječe ubrzanje automobila u smjeru kretanja.


7.1. Testiranje Toyota Yaris

Ovaj automobil korišten je za ispitivanje mogućnosti prikupljanja podataka te njihovog prikaza s namjerom praćenja rezultata kroz godišnji period u svrhu prepoznavanja istrošenosti i oštećenja sustava ovjesa automobila. Zabilježeni su zapisi vožnje po veoma lošoj cesti, sporijom brzinom (20 km/h) te su prikazani na slikama: Slika 18 i Slika 19. Ovim testiranjem zaključeno je da je sustav sposoban bilježiti dovoljno brzo velik raspon udara i vibracija.

Kako sami rezultati ovise i o brzini kretanja automobila te u ovom trenutku još nisu uvedeni filteri koji bi vrijednosti ispravljali neovisno o brzini, stoga se rasponi vrijednosti razlikuju na različitim prometnicama te je testiranje potrebno prilagoditi specifičnoj brzini.



Slika 18. Prikaz RQ vrijednosti na karti (ulica Potok)




Slika 19. Grafički prikaz vrijednosti sa karte (ulica Potok)

Kako bismo mogli pratiti ponašanje ovjesa potrebno je zabilježiti njegovo ponašanje u točno određenim uvjetima. Uvjeti testiranja postavljeni su tako da je odabrana ulica s dobrom kvalitetom asfalta s dva ležeća policajca čija je uloga da simuliraju pobudu tj. neravninu na cesti točno određenih dimenzija, koje se ne će mijenjati kroz duži vremenski period za potrebna buduća testiranja.


Uvjeti u kojima je testirano:

- Model automobila: Toyota Yaris 2003
- Dimenzije i vrsta guma: 185/65-R15, ljetne
- Tlak u gumama: 2.4 bar
- Broj putnika: 1
- Razina goriva u spremniku: pun spremnik
- Brzina: 20 km/h

Navedeni parametri utječu na iznose izmjerenih vrijednosti. Dimenzije, vrsta i tlak guma utječu na njeno savijanje prilikom nailaska na neravninu, razina spremnika i broj putnika utječu na masu vozila dok brzina vozila na njegovu inerciju. Rezultati su prikazani grafički slikom 20. i slikom 21. Vrijednosti prikazane na slici 21. daju nam podatke o izmjerenim vertikalnim trzajima na karoseriji automobila. Prilikom oštećenja na ovjesu automobila sustav bi trebao zabilježiti povećane vrijednosti koje su rezultat povećanih udara zbog nepravilnih dijelova ovjesa. Vrijednosti koje su prikazane na slici 20. daju nam podatke o izmjerenim maksimalnim vertikalnim ubrzanjima karoserije automobila. Pomoću takvog grafičkog prikaza možemo pratiti koliko je automobilu potrebno da se vrati u stanje ravnoteže nakon prolaska preko neravnine. Podatak koji ukazuju na oštećenja amortizera je povećano ljuljanje vozila, takvom automobilu potrebno je više vremena (veći put) da se vrati u stanje ravnoteže. Za takav automobil krivulja vrijednosti imala bi manji nagib te bi njen skok bio širi zbog većeg prijednog puta.



Slika 20. Grafički prikaz vrijednosti pomoću maxAccbByLocation




Slika 21. Grafički prikaz vrijednosti pomoću avgJerkByLocation

Na temelju ovih podataka potrebno je raditi testiranje svaka 4 mjeseca kako bi se uočila eventualna odstupanja. Također poželjno je tokom tehničkog pregleda vozila zabilježiti vrijednosti na uređaju za testiranje podvozja te usporediti razliku vrijednosti između dva pregleda s razlikom zabilježenih RQ vrijednosti unutar godine dana.

7.2. Testiranje Citroen C5


Napravljeno je testiranje na temelju analize pasivnog i aktivnog (mogućnost smanjenja tvrdoće ovjesa) ovjesa prema knjizi Dr. Rajesh Rajamani, knjiga „Vehicle Dynamics and Control“ [17], gdje su prikazani rezultati (Slika 22) ponašanja dva tipa ovjesa nailaskom na neravninu. Da bismo utvrdili može li sustav zabilježiti i prepoznati na istom automobilu različito podešen ovjes, korišten je automobil Citroen C5 s mogućnošću promjene tvrdoće ovjesa (Sport i Comfort mod). Testiranje je napravljeno u svrhu prilagodbe ovjesa prema nadolazećoj prometnici te planiranje optimalne rute između odredišnih točaka. Takav ovjes trebao bi spriječiti oštećenja na sustavu ovjesa te smanjiti njegovo trošenje.




Slika 22. Usporedba aktivnog i pasivnog ovjesa[17]

Zabilježena su dva zapisa podataka na odabranoj prometnici pri jednakoj brzini, ali kod različito podešenih ovjesa (modova). Odabrana je cesta srednje kvalitete s nekoliko izraženijih oštećenja. Dobiveni rezultati prikazani su grafički na slikama: Slika 23. i Slika 24. RQ vrijednosti kod tvrde podešenog ovjesa (Sport mode) 15 - 20% su veći od rezultata dobivenih kod mekanije podešenog ovjesa (Comfort mode).

Usporedbom zabilježenih RQ vrijednosti zaključujemo da je sustav sposoban davati na temelju trenutnih i ranije prikupljenih podataka informacije za podešavanje ovjesa automobila, te tako povisiti razinu udobnosti u vožnji.



Slika 23. Grafički prikaz Citroen Sport mode



Slika 24. Grafički prikaz Citroen Comfort mode

8. ZAKLJUČAK

Konačnim testiranjem rada sustava za praćenje udobnosti vožnje potvrđena je izvedivost pomoću mobilne aplikacije i pametnog telefona. Prikazani rezultati pokazuju da je sustav u stvarnosti sposoban bilježiti rezultate s dovoljno velikom osjetljivošću. Vlasnici automobila tako mogu pratiti stanje sustava ovjesa te uz iscrtanu kartu s RQ vrijednostima prilagođavati brzinu, ali i stupanj tvrdoće ovjesa. Ovlašteni serviseri i zastupnici automobila uz pomoć RQ vrijednosti mogu prilagoditi vremenske periode i zahtjeve za održavanjem vozila. Ovakav sustav može se koristiti kao pokazatelj da li je kvar na ovjesu automobila zaista uklonjen, usporedbom RQ vrijednosti prije i nakon servisa.

Prilikom izrade aplikacije otklonjeno je nekoliko problema koji utječu na usporedivost RQ vrijednosti, kao što su položaj pametnog telefona u automobilu i ubrzanje automobila. Da bi zabilježili razliku između RQ vrijednosti više mjerenja potrebna je velika osjetljivost sustava. Zbog velike osjetljivosti, na RQ vrijednost utječu razni faktori kao što su: dimenzije guma, tlak u gumama, broj putnika, model automobila. Poželjno bi bilo povezati pametni telefon sa standardnim automobilskim priključkom (OBD2) kako bi sustav sam očitavao podatke o vozilu bez potrebe da ih korisnik sam unosi.

Kako bi sustav mogao imati širu primjenu za različita vozila potrebno je definirati uvjete pri kojim bi se bilježile referentne RQ vrijednosti te zabilježiti vrijednosti na novim automobilima. Uz definirane uvjete testiranja moguće je odrediti granice vrijednosti koje bi ukazivale na određena oštećenja, ali i korigirati dozvoljena odstupanja. Tako zabilježenim RQ vrijednostima bilo bi moguće pratiti eventualna povećanja vrijednosti u dužem vremenskom razdoblju koja bi ukazivala na razna oštećenja i istrošenost dijelova ovjesa.

Također potrebno je omogućiti građanima da svoje vrijednosti spremaju na server kako bi mogli uspoređivati rezultate s drugim korisnicima. Zbog naglog razvoja pametnih sustava u automobilima ostavlja se mogućnost povezivanja pametnog telefona i Road Quality sustava s pametnim sustavom automobila, te korištenjem njegovih senzora i podataka.

Sustav je uz osnovnu primjenu praćenja stanja sustava ovjesa pogodan i za daljnji razvoj u pogledu planiranja optimalne rute kao navigacijski uređaj te za prikaz stanja oštećenosti cesta koji bi koristile gradske vlasti u svrhu planiranja popravaka.

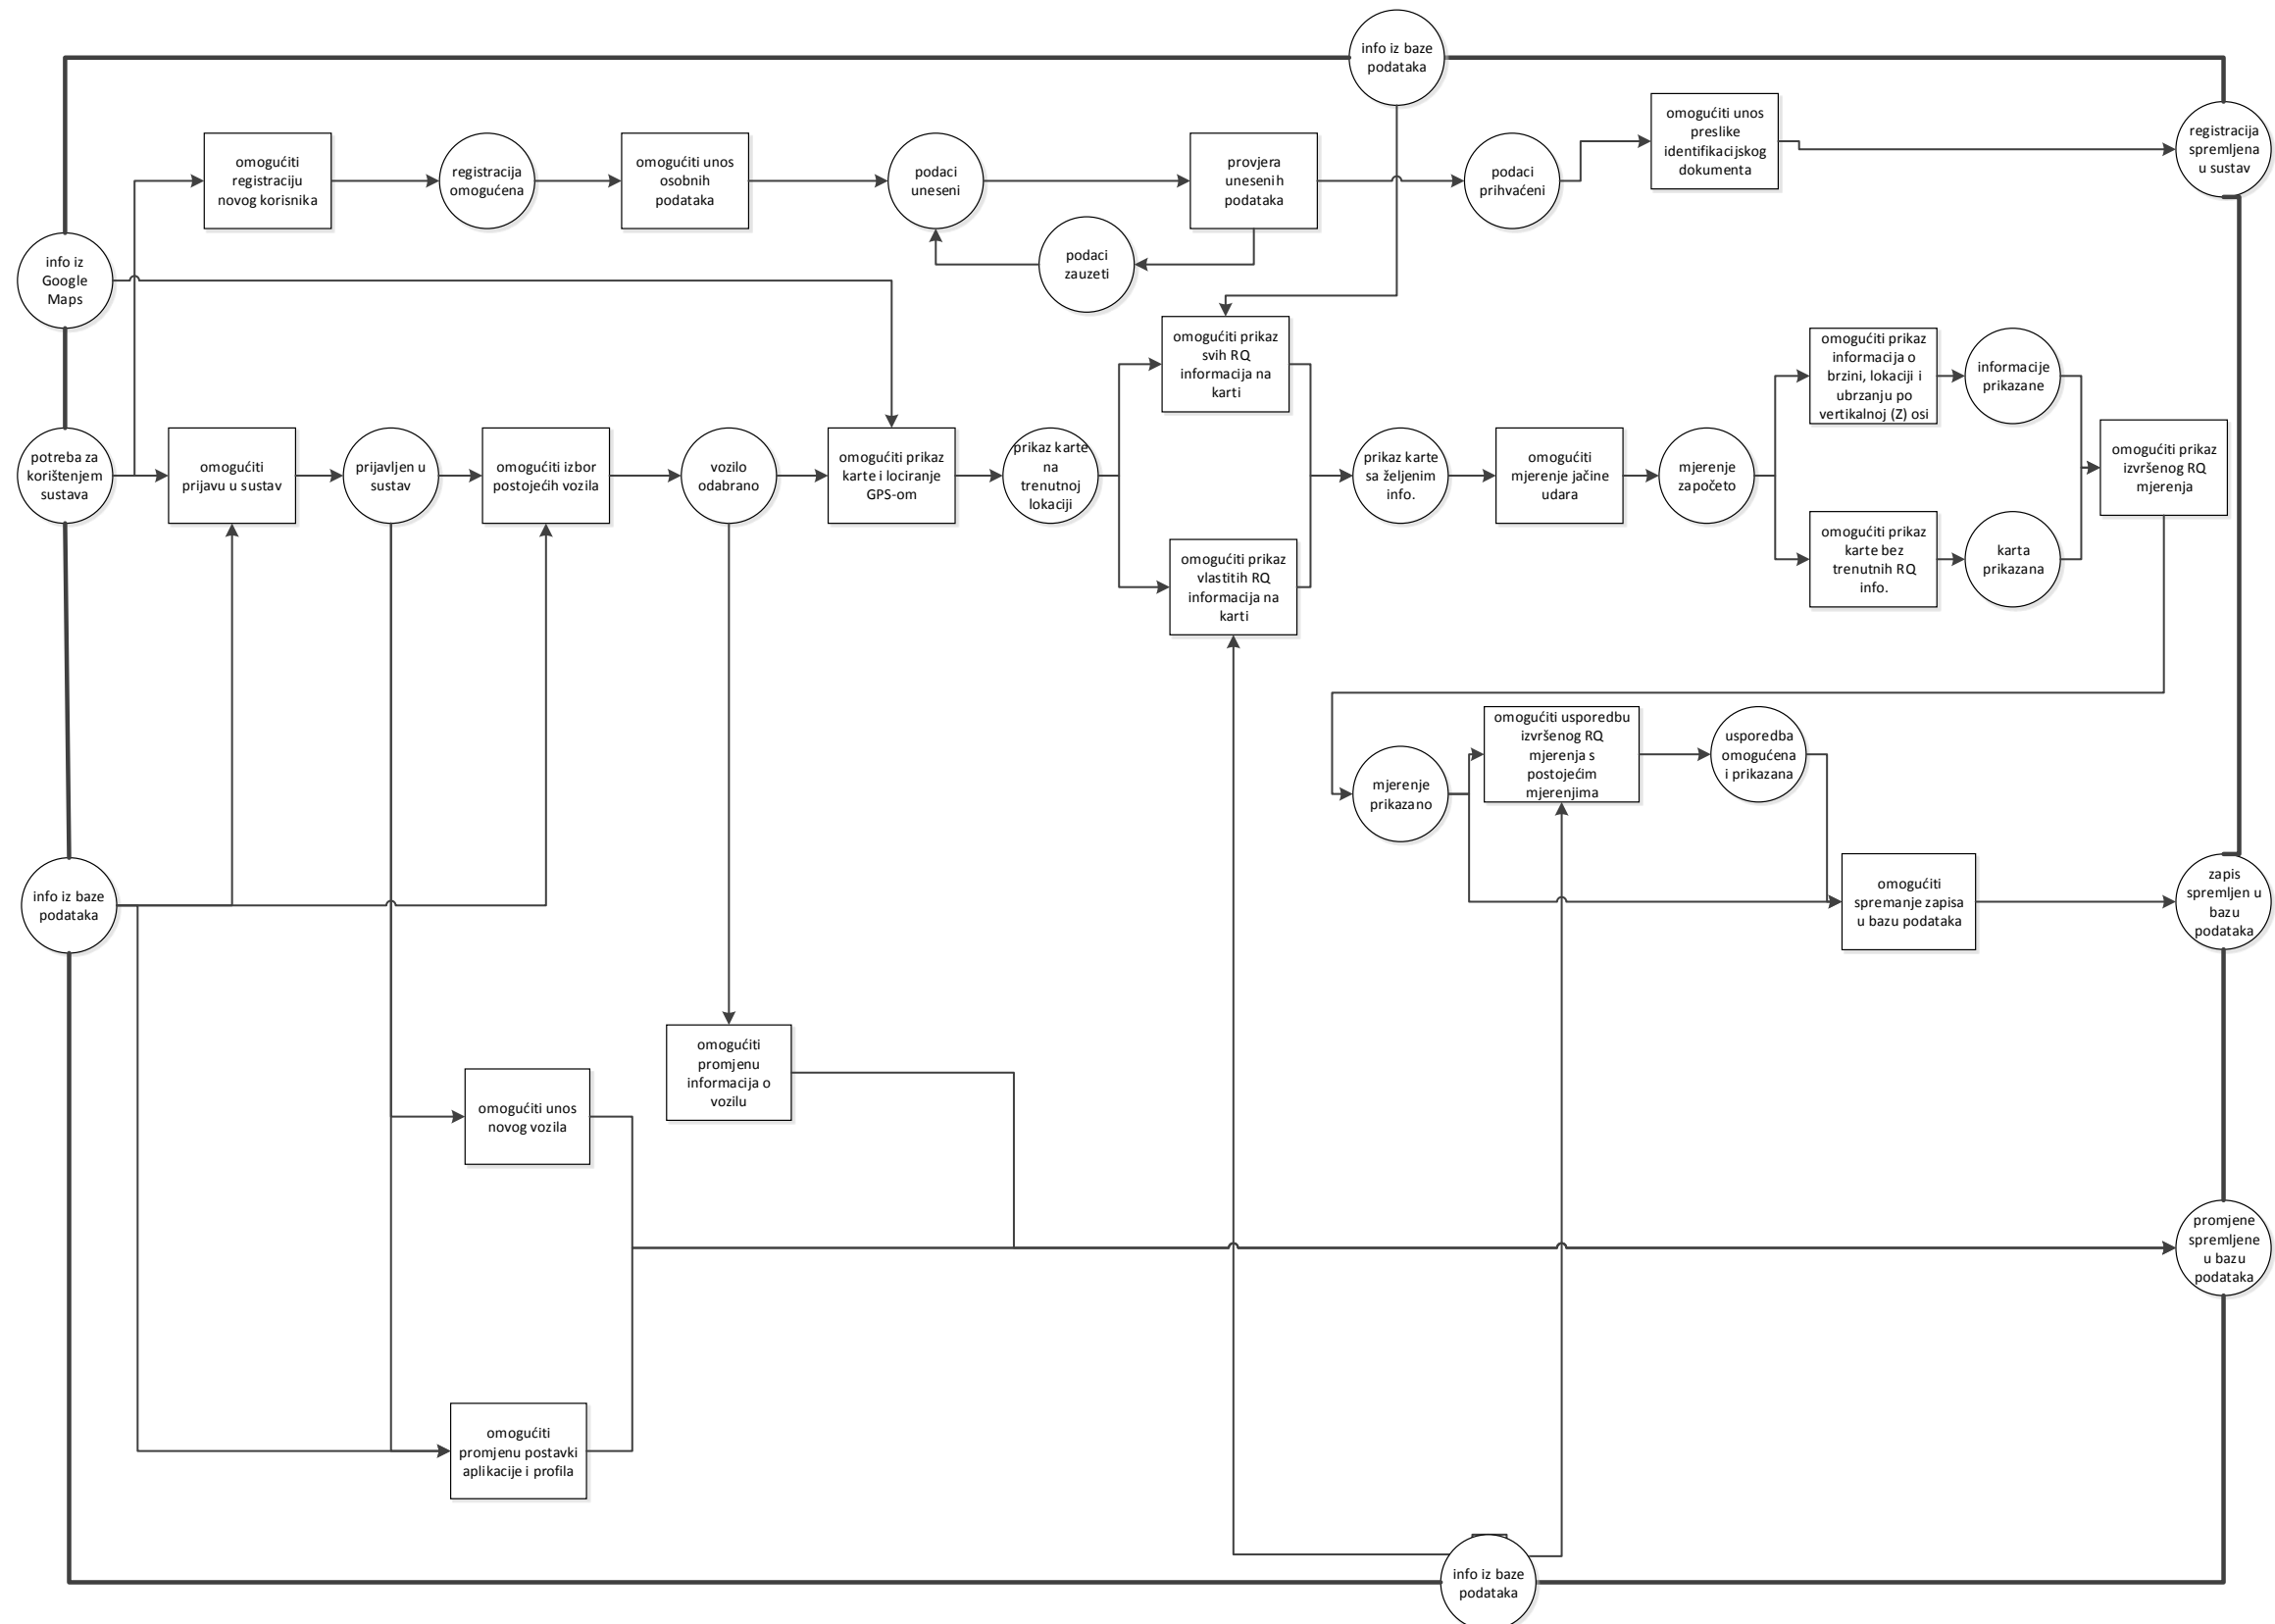
Zbog ograničenog vremena prilikom izrade ovog rada, ali i ograničene uporabe različitih mobilnih uređaja i automobila sustav je u testnoj fazi i s ograničenim funkcijama. Sustav je predviđen za daljnji razvoj te je potrebno bilježiti vrijednosti u duljem vremenskom razdoblju kako bi se utvrdile promjene na sustavu ovjesa automobila .

9. LITERATURA

- [1] Heidy van Beurden – Smart City dynamics, HvB Communicatie, Amsterdam, 2011.
- [2] Living Lab
<http://www.fer.unizg.hr/news/56261/070-071%20FER%20energetika.pdf>
- [3] CarPlay
<http://www.apple.com/ios/carplay/>
- [4] HAK-stanje državnih prometnica
<http://www.hak.hr/vijest/400/hak-lokalne-prometnice-su-lose>
- [5] Magic body control
<http://www.mercedes-benz.hr>
- [6] Tokić-ispitivanje sustava ovjesa automobila
http://www.tokic.hr/images/techInfo/pdf_6.pdf
- [7] Accelerometer Frequency
<https://play.google.com/store/apps/details?id=com.cochibo.accfreq&hl=en>
- [8] Sensor Logger
<https://play.google.com/store/apps/details?id=net.uninc.sensorlogger&hl=en>
- [9] Modeliranje i simulacije
http://www.etfos.unios.hr/upload/OBAVIJESTI/obavijesti_preddiplomski/Modeliranje_i_simulacija_av01_09-11-2009.pdf
- [10] Informacijski modeli proizvoda-Funkcijsko modeliranje proizvoda, FSB
www.cadlab.fsb.hr
- [11] Eclipse Standard
<http://www.eclipse.org/>
- [12] Installing the Eclipse Plugin-Android developers
<http://developer.android.com/sdk/installing/installing-adt.html>
- [13] LogoMaker
<http://www.logomaker.com/>
- [14] Aplikacijsko programsko sučelje
<http://hr.wikipedia.org/wiki/API>
- [15] Pat Niemeyer, Jonathan Knudsen-Learning Java, O'Reilly, 2000.
- [16] GPSVizualizer
<http://www.gpsvisualizer.com/>


- [17] Rajesh Rajamani – Vehicle Dynamics and Control, University of Minnesota, Department of Mechanical Engineering, 2012.
- [18] Li Li, Fei-Yue Wang– Advanced Motion Control and Sensing for Intelligent Vehicles, University of Arizona, Department of Systems and Industrial Engineering, 2007.

10.1. Model funkcija sustava pomoću toka



10.2. EXPRESS-G diagram podataka

Road Quality Mapping – Express G diagram



10.3. UML dijagram aktivnosti

